

PREDIKSI HARGA SAHAM PT TELKOM MENGGUNAKAN METODE CNN-LSTM

Ferdian Rizki Pratama¹⁾, Budi Santoso²⁾, Slamet Kacung³⁾

^{1,2,3)} Teknik Informatika Universitas Dr. Soetomo

email : ferrrdian18@gmail.com¹⁾, budi.santoso@unitomo.ac.id²⁾, slamet@unitomo.ac.id³⁾

Abstraksi

PT Telkom sebagai perusahaan informasi dan komunikasi terbesar di Indonesia, memiliki harga saham yang menarik minat investor. Penelitian ini bertujuan untuk mengembangkan aplikasi yang mampu memprediksi harga saham PT Telkom menggunakan metode CNN-LSTM. Tantangan dalam memprediksi harga saham meliputi volatilitas pasar, keterbatasan data historis, dan kompleksitas faktor-faktor yang mempengaruhi harga. Metode CNN digunakan untuk mengenali pola spasial dalam data, sementara LSTM mengatasi masalah vanishing gradient dan menangkapi dependensi jangka panjang. Model CNN-LSTM diuji dengan berbagai kombinasi hyperparameter, termasuk learning rate (0.001, 0.0001, dan 0.0005), kernel size (3, 5, dan 7), dan jumlah epoch (30, 50, dan 100). Hasil terbaik diperoleh dengan konfigurasi learning rate 0.0005, kernel size 7, dan 100 epoch, yang menghasilkan nilai Mean Absolute Error (MAE) sebesar 56.13, Root Mean Squared Error (RMSE) sebesar 75.75, dan koefisien determinasi (R^2) sebesar 0.973. Hasil ini menunjukkan kemampuan prediksi yang baik dari model. Penelitian ini diharapkan dapat memberikan solusi bagi investor dalam memprediksi harga saham PT Telkom dan membantu pengambilan keputusan investasi.

Kata Kunci :

CNN-LSTM, Hyperparameter, Prediksi Harga Saham, PT Telkom, Time Series.

Abstract

PT Telkom as the largest information and communication company in Indonesia, has stock prices that attract investors. This research aims to develop an application capable of predicting PT Telkom's stock prices using the CNN-LSTM method. Challenges in stock price prediction include market volatility, limited historical data, and the complexity of factors influencing prices. The CNN method is used to recognize spatial patterns in the data, while LSTM addresses the vanishing gradient problem and captures long-term dependencies. The CNN-LSTM model was tested with various hyperparameter combinations, including learning rates (0.001, 0.0001, and 0.0005), kernel sizes (3, 5, and 7), and the number of epochs (30, 50, and 100). The best results were obtained with a configuration of a learning rate of 0.0005, a kernel size of 7, and 100 epochs, which yielded a Mean Absolute Error (MAE) of 56.13, a Root Mean Squared Error (RMSE) of 75.75, and a coefficient of determination (R^2) of 0.973. These results demonstrate the model's good predictive ability. This research is expected to provide solutions for investors in predicting PT Telkom's stock prices and assist in investment decision-making.

Keywords :

CNN-LSTM, Hyperparameter, PT Telkom, Stock Price Prediction, Time Series.

Pendahuluan

Perkembangan teknologi informasi telah berperan signifikan dalam meningkatkan minat masyarakat terhadap dunia investasi, terutama di kalangan generasi muda. Salah satu instrumen investasi yang paling diminati adalah saham. Saham menawarkan potensi tingkat pengembalian yang tinggi, likuiditas yang baik, serta kemudahan dalam proses transaksi yang disediakan oleh aplikasi fintech. Ketertarikan generasi muda terhadap investasi di pasar modal melalui teknologi fintech didorong oleh faktor minat pribadi dan lingkungan sosial, bukan semata-mata oleh literasi keuangan[1]. Temuan ini menunjukkan bahwa kemajuan teknologi, dikombinasikan dengan motivasi individu dan pengaruh sosial, telah

mendorong peningkatan signifikan jumlah investor muda yang aktif di pasar modal[1]. Kehadiran teknologi digital tidak hanya memperluas akses terhadap instrumen keuangan, tetapi juga membentuk pola baru dalam pengambilan keputusan investasi generasi muda.

Salah satu saham yang banyak diminati adalah milik PT Telkom merupakan perusahaan komunikasi terbesar di Indonesia. Kinerja dan reputasi perusahaan yang baik menjadikan saham PT. Telkom sebagai salah satu aset yang menarik untuk diinvestasikan[2].

Namun, pergerakan harga saham sangat fluktuatif dan dipengaruhi oleh berbagai faktor seperti kondisi ekonomi makro, kebijakan pemerintah, situasi politik, serta sentimen pasar baik lokal maupun global[3]. Ketidakpastian ini menjadikan proses prediksi harga saham sebagai tantangan besar bagi para investor, terutama dalam mengambil keputusan investasi yang tepat waktu dan menguntungkan. Faktor-faktor eksternal yang tidak dapat dikendalikan sering kali menyebabkan volatilitas harga yang tinggi, sehingga analisis konvensional menjadi kurang efektif dalam menangkap pola yang dinamis dan kompleks tersebut. Pendekatan konvensional seperti analisis teknikal dan fundamental sering kali belum cukup dalam memberikan prediksi yang akurat, karena tidak selalu dapat menangkap pola kompleks dan dinamis yang terjadi dalam pergerakan harga saham.

Pemanfaatan teknologi *deep learning* dapat digunakan untuk memodelkan pola pergerakan harga saham dengan lebih efektif. *Deep learning* adalah cabang dari machine learning yang menggunakan jaringan saraf tiruan dengan banyak lapisan untuk memodelkan hubungan yang kompleks dalam data besar[4]. Kemampuan dalam mengidentifikasi pola non-linier dan memproses data dalam jumlah besar menjadikan *deep learning* digunakan dalam berbagai bidang termasuk di bidang citra digital, pemrosesan bahasa alami, dan prediksi pasar. Teknik ini telah berkembang pesat berkat kemajuan dalam komputasi dan ketersediaan data besar. Tujuan dari penelitian ini adalah untuk membangun model prediksi harga saham PT Telkom menggunakan metode CNN-LSTM guna meningkatkan akurasi prediksi melalui pendekatan fitur spasial-temporal.

Tinjauan Pustaka

Sejumlah penelitian sebelumnya telah mencoba untuk memprediksi harga saham dengan menggunakan berbagai metode. Penelitian sebelumnya menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA) untuk memprediksi harga saham GOTO, dengan nilai *mean absolute percentage error* (MAPE) sebesar 1,31% untuk 372 data dan 1,82% untuk 165 data[2].

Selanjutnya, metode dari ranah *machine learning* seperti *Support Vector Regression* (SVR) telah digunakan untuk prediksi harga saham PT Anabatic Technologies Tbk (ATIC) dengan data historis harian dari 01 Januari 2017 hingga 31 Desember 2021. Penentuan *hyperparameter* dengan performa terbaik pada penelitian ini menggunakan GridSearchCV. Dari beberapa jenis kernel yang diuji, model SVR dengan kernel linier memberikan hasil terbaik dengan *hyperparameter* Cost (C)=1 dan epsilon (ϵ)=0,11. Model terbaik ini menghasilkan *mean squared error* (MSE) sebesar 0,001237173, *Symmetric Mean Absolute Percentage Error* (SMAPE) sebesar 0,1167301, dan $R^2 = 0,9206643$ [5].

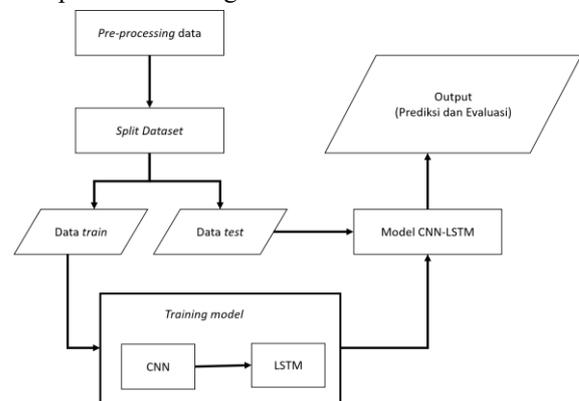
Penelitian lain berfokus pada prediksi harga saham syariah dengan memanfaatkan algoritma *Recurrent Neural Network* (RNN) dengan menggunakan data harga pembukaan saham ADRO dari tahun 2020 hingga 2024 yang diperoleh dari Google Finance yang melalui pengujian terhadap 12 konfigurasi model, diperoleh hasil terbaik pada skenario dengan 2 hidden layer, masing-masing berisi 100 unit, 150 epoch, dan dropout sebesar 10% menghasilkan akurasi prediksi sebesar 98,2% dan nilai RMSE sebesar 106[4].

Metode *Long Short-Term Memory* (LSTM) juga telah digunakan dalam memprediksi harga saham PT Telkom dengan data harian dari tahun 2018 hingga 2023 (1.493 data) serta data setelah pandemi Covid-19 dari 2021 hingga 2023 (732 data). Optimasi parameter dilakukan dengan berbagai kombinasi *neuron* lapisan tersembunyi, *batch size*, dan *epoch*, menghasilkan hasil terbaik pada konfigurasi 4 *neuron*, *batch size* 64, dan 80 *epoch* dengan nilai MAPE sebesar 1,016% [6].

Sementara itu, penelitian lain menunjukkan bahwa model gabungan CNN-LSTM berhasil meningkatkan akurasi prediksi produksi gas lapangan dibandingkan dengan berbagai metode lainnya, termasuk model LSTM tunggal. Model CNN-LSTM menghasilkan rata-rata kesalahan MAPE bulanan sebesar 7,7%, jauh lebih rendah dibandingkan metode lain seperti RNN (18%), *Random Forest* (23,17%), ARIMA (25,3%), dan LSTM (46%)[7]. Metode ini menunjukkan potensi besar untuk meningkatkan kinerja prediksi pada data yang bersifat fluktuatif dan kompleks seperti harga saham.

Metode Penelitian

Penelitian ini menggunakan metode pemodelan *deep learning* dengan arsitektur gabungan CNN-LSTM untuk memprediksi dan mengevaluasi nilai berdasarkan data historis. Alur proses secara umum ditunjukkan pada Gambar 1 yang terdiri dari beberapa tahapan utama sebagai berikut:



Gambar 1 Alur proses prediksi CNN-LSTM

Pre-processing data

Proses dimulai dengan memasukkan dataset harga saham PT Telkom untuk periode tahun 2012 hingga

2025. Dari dataset tersebut, peneliti memilih harga penutupan (*close*) yang digunakan dalam proses pelatihan model karena harga penutupan dianggap paling representatif dalam mencerminkan kondisi akhir pasar setiap harinya. Dataset tersebut kemudian melalui beberapa tahap pre-processing data yaitu *forward filling* untuk menangani nilai yang hilang dengan mengisi berdasarkan nilai sebelumnya, normalisasi dataset agar seluruh nilai berada dalam rentang seragam guna meningkatkan stabilitas pelatihan, serta pembagian dataset menjadi data latih dan data uji. Persentase pembagian antara data latih dan uji adalah 80:20.

Pelatihan Model (CNN-LSTM)

setelah tahap *pre-processing* selesai, dilakukan inialisasi *hyperparameter* awal yang diperlukan dalam pembangunan model agar diperoleh hasil yang maksimal. Proses pencarian nilai *hyperparameter* yang optimal dikenal dengan istilah *hyperparameter tuning*[8]. Parameter yang digunakan dalam proses *hyperparameter tuning* pada penelitian ini mencakup 3 hal, yaitu learning rate (0.001, 0.0001, dan 0.0005), kernel size (3,5, dan 7) dan epoch (30,50, dan 100) Pada bagian *Convolutional Neural Network* (CNN), digunakan CNN 1 dimensi yang khusus untuk memproses data satu dimensi seperti *time series*. Diterapkan metode konvolusi dengan rumus sebagai berikut :

$$Z(t) = \sum_{i=1}^k \sum_{j=1}^F W(i,j) \cdot X(t+i-1,j) + b \quad (1)$$

dimana $Z(t)$ merupakan hasil konvolusi pada waktu ke- t , X adalah data input dengan panjang waktu dan jumlah fitur F , W adalah bobot dari kernel berukuran $k \times F$, dan b adalah bias. Setiap filter melakukan operasi dot product antara kernel dan input lokal untuk menghasilkan feature map yang merepresentasikan pola-pola penting dalam urutan data[9].

Output pada bagian CNN akan diteruskan pada lapisan LSTM dengan rumus sebagai berikut :

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (2)$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (3)$$

$$\tilde{C}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (4)$$

$$C_t = (i_t \times \tilde{C}_t + f_t \times C_{t-1}) \quad (5)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (6)$$

$$h_t = o_t \times \tanh(C_t) \quad (7)$$

LSTM memiliki mekanisme gerbang yang dirancang untuk mengatasi masalah vanishing gradient pada jaringan syaraf berulang (RNN) tradisional[10][11].

Mekanisme ini melibatkan beberapa gerbang utama, yaitu *forget gate* (2), *input gate* (3), *candidate cell state* (4), *cell state* (5), *output gate* (6) dan *hidden state*(7). *Forget gate* menentukan bagian informasi dari keadaan sebelumnya C_{t-1} yang harus dilupakan, sedangkan *input gate* mengatur informasi baru yang akan ditambahkan ke dalam sel memori melalui C_t . Selanjutnya, nilai *cell state* diperbarui dengan menggabungkan informasi lama dan baru, sedangkan *output gate* mengontrol bagian dari *cell state* yang akan diteruskan sebagai output dalam bentuk *hidden state*. Fungsi aktivasi *sigmoid* σ dan *tanh* digunakan untuk mengatur sinyal yang mengalir melalui setiap gerbang, menjaga kestabilan pembelajaran.

Output (Prediksi dan Evaluasi)

Hasil prediksi divisualisasikan dalam bentuk grafik perbandingan antara nilai aktual dan nilai prediksi untuk memberikan gambaran visual tentang akurasi model dalam mengikuti pola data historis. Selain itu, model dievaluasi menggunakan beberapa metrik evaluasi regresi seperti MAE, RMSE, dan koefisien determinasi (R^2). Evaluasi dilakukan secara iteratif terhadap setiap kombinasi *hyperparameter* untuk menentukan konfigurasi yang menghasilkan performa terbaik. Di antara ketiga metrik tersebut, RMSE dipilih sebagai metrik utama dalam proses pemilihan *hyperparameter* karena memiliki sensitivitas yang lebih tinggi terhadap kesalahan prediksi yang besar. Tidak seperti MAE yang memberikan bobot yang sama untuk semua kesalahan, RMSE menghitung akar kuadrat dari selisih kuadrat antara nilai prediksi dan nilai aktual, sehingga penalti terhadap outlier menjadi lebih signifikan[12]. Hal ini menjadikan RMSE sangat cocok digunakan dalam konteks di mana deviasi prediksi terhadap nilai aktual perlu diminimalkan secara ketat dan dalam satuan yang sama dengan target output.

Hasil dan Pembahasan

Pelatihan dan pengujian model CNN-LSTM dilakukan dengan menerapkan kombinasi *hyperparameter* yang terdiri dari tiga nilai untuk masing-masing dari tiga parameter utama, yaitu learning rate, kernel size, dan jumlah epochs. Kombinasi ini menghasilkan total 27 konfigurasi berbeda yang dinilai dengan nilai RMSE terkecil. Hasil evaluasi dari masing-masing kombinasi ditampilkan pada Tabel 1.

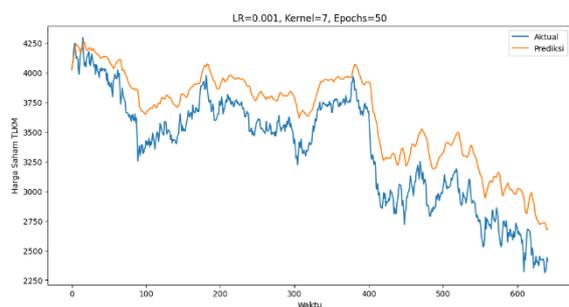
Tabel 1 hasil kombinasi *hyperparameter*

Learning Rate	Kernel Size	Epochs	MAE	RMSE	R ²
0.0005	7	100	56.13	75.75	0.973
0.0005	5	50	59.19	78.55	0.971
0.0010	3	100	64.04	82.44	0.968
0.0005	5	100	62.95	82.84	0.968

0.0005	3	100	70.08	89.51	0.963
0.0010	5	100	74.03	94.53	0.958
0.0001	7	100	72.77	95.48	0.958
0.0010	3	50	73.87	96.50	0.957
0.0001	5	100	79.95	98.87	0.955
0.0010	7	100	81.83	99.59	0.954
0.0010	3	30	76.42	101.01	0.953
0.0010	5	50	90.93	113.46	0.940
0.0001	3	100	93.94	118.45	0.935
0.0001	3	30	89.10	119.70	0.933
0.0010	7	30	94.41	124.89	0.927
0.0005	3	30	99.32	125.66	0.927
0.0005	5	30	96.17	126.37	0.926
0.0001	5	50	96.13	126.99	0.925
0.0001	5	30	95.57	127.63	0.924
0.0001	3	50	99.33	128.62	0.923
0.0005	7	50	105.81	130.83	0.920
0.0005	7	30	108.98	139.34	0.910
0.0001	7	50	124.88	156.62	0.886
0.0001	7	30	121.83	157.70	0.884
0.0005	3	50	183.72	203.27	0.808
0.0010	5	30	177.80	204.06	0.806
0.0010	7	50	278.77	299.80	0.582

Kombinasi *hyperparameter* dengan performa paling rendah

Kombinasi dengan performa paling rendah ditemukan pada konfigurasi *learning rate* 0.001, *kernel size* 7, dan 50 *epochs* yang dapat dilihat pada gambar 2.



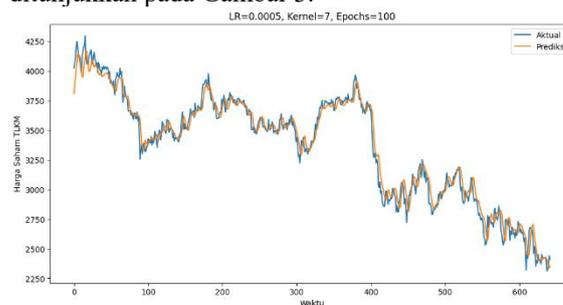
Gambar 2 grafik model kombinasi *hyperparameter* dengan performa paling rendah

pada konfigurasi ini, model mencatat nilai MAE sebesar 278.77, RMSE sebesar 299.80, dan R^2 yang jauh lebih rendah, yakni 0.582. Gambar 2 menunjukkan bahwa prediksi dari model tersebut tidak mampu mengikuti pola fluktuatif dari harga aktual. Model cenderung menghasilkan prediksi yang lebih halus dan tidak responsif terhadap perubahan mendadak, yang dapat diakibatkan oleh proses

pembelajaran yang terlalu cepat akibat nilai *learning rate* yang tinggi dan jumlah *epoch* yang belum mencukupi untuk mencapai konvergensi.

Kombinasi *hyperparameter* dengan performa terbaik

Kombinasi *hyperparameter* dengan performa terbaik ditemukan pada konfigurasi *learning rate* 0.0001, *kernel size* 3, dan 100 *epochs*, sebagaimana ditunjukkan pada Gambar 3.



Gambar 3 grafik hasil kombinasi *hyperparameter* dengan performa terbaik

pada konfigurasi ini, model mencatat MAE sebesar 87,14, RMSE sebesar 106,42, dan R^2 sebesar 0,942, yang menunjukkan bahwa model mampu menjelaskan sebagian besar variabilitas harga saham dan meminimalkan kesalahan prediksi. Gambar 3 memperlihatkan bahwa hasil prediksi mengikuti pola pergerakan harga aktual dengan lebih akurat, termasuk dalam menangkap tren naik turun yang bersifat fluktuatif.

Kinerja optimal ini kemungkinan besar disebabkan oleh nilai *learning rate* yang rendah, yang memungkinkan model belajar secara bertahap tanpa melewati solusi optimal, serta jumlah *epoch* yang cukup besar yang memberi waktu bagi model untuk berkonvergensi secara menyeluruh. Selain itu, ukuran *kernel* yang kecil membantu dalam menangkap pola lokal dari urutan waktu, sehingga model dapat mengenali fitur-fitur penting secara detail dan meningkatkan akurasi prediksi pada variasi jangka pendek.

Kesimpulan dan Saran

Berdasarkan hasil evaluasi terhadap 27 kombinasi parameter pada model hybrid CNN-LSTM, diperoleh bahwa performa terbaik dicapai dengan konfigurasi *learning rate* sebesar 0.0005, *kernel size* 7, dan jumlah *epoch* sebanyak 100. Kombinasi ini menghasilkan nilai MAE sebesar 56.13, RMSE sebesar 75.75, dan R^2 sebesar 0.9733. Hasil ini menunjukkan bahwa model memiliki kemampuan prediksi yang sangat baik, dengan galat yang rendah dan akurasi yang tinggi.

Secara umum, peningkatan jumlah *epoch* hingga 100 cenderung meningkatkan performa model, asalkan

tidak terjadi overfitting. Di sisi lain, pemilihan *learning rate* yang terlalu tinggi, seperti 0.0010, cenderung menghasilkan performa yang kurang stabil dan akurasi yang menurun. Sementara itu, kernel size yang lebih besar misalnya 7 terbukti lebih efektif dalam mengekstraksi pola temporal pada data deret waktu dibandingkan kernel yang lebih kecil. Model dengan performa terburuk ditemukan pada kombinasi *learning rate* 0.0010, kernel size 7, dan epoch 50, dengan nilai MAE sebesar 278.77, RMSE sebesar 299.80, dan R^2 sebesar 0.5817. Hal ini mengindikasikan bahwa pemilihan parameter yang kurang tepat dapat berdampak signifikan terhadap kemampuan prediktif model.

Daftar Pustaka

- [1] J. Martin Pesireron, R. Kusumawardhani, and R. Rinofah, "Young Investors Interest in Investing in The Capital Market Through Fintech Technology," *Indones. J. Econ.*, vol. 02, no. 05, pp. 48–58, 2024.
- [2] I. L. Senjaya, "Analisis Valuasi Saham Bumn Menggunakan Metode Dividend Discounted Model Dan Economic Value Added," *J. Adm. Bisnis*, vol. 17, no. 2, pp. 115–128, 2021, doi: 10.26593/jab.v17i2.5022.115-128.
- [3] M. Zidan Rusminto, S. Adi Wibowo, and F. Santi Wahyuni, "Peramalan Harga Saham Menggunakan Metode Arima (Autoregressive Integrated Moving Average) Time Series," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 2, pp. 1263–1270, 2024, doi: 10.36040/jati.v8i2.9089.
- [4] X. Ji, J. Wang, and Z. Yan, "A stock price prediction method based on deep learning technology," *Int. J. Crowd Sci.*, vol. 5, no. 1, pp. 55–72, 2021.
- [5] A. W. Ishlah, S. Sudarno, and P. Kartikasari, "Implementasi Gridsearchcv Pada Support Vector Regression (Svr) Untuk Peramalan Harga Saham," *J. Gaussian*, vol. 12, no. 2, pp. 276–286, 2023, doi: 10.14710/j.gauss.12.2.276-286.
- [6] H. Nazhiroh, D. Fitria, and D. Permana, "PT . Telkom (Tbk) Stock Price Forecasting Using Long Short Term Memory (LSTM)," vol. 2, no. 2020, pp. 414–421, 2024.
- [7] W. Zha *et al.*, "Forecasting monthly gas field production based on the CNN-LSTM model," *Energy*, vol. 260, p. 124889, 2022.
- [8] A. Morales-Hernández, I. Van Nieuwenhuysse, and S. Rojas Gonzalez, *A survey on multi-objective hyperparameter optimization algorithms for machine learning*, vol. 56, no. 8. Springer Netherlands, 2023. doi: 10.1007/s10462-022-10359-2.
- [9] S. Liu, C. Zhang, and J. Ma, "CNN-LSTM neural network model for quantitative strategy analysis in stock markets," in *Neural Information Processing: 24th International Conference, ICONIP 2017, Guangzhou, China, November 14-18, 2017, Proceedings, Part II 24*, Springer, 2017, pp. 198–206.
- [10] I. K. A. Enriko, F. Nizar Gustiyana, and R. H. Putra, "Komparasi Hasil Optimasi Pada Prediksi Harga Saham PT. Telkom Indonesia Menggunakan Algoritma Long Short Term Memory," *J. Media Inform. Budidarma*, vol. 7, no. 2, pp. 659–667, 2023, doi: 10.30865/mib.v7i2.5822.
- [11] S. J. Pipin, R. Purba, and H. Kurniawan, "Prediksi Saham Menggunakan Recurrent Neural Network (RNN-LSTM) dengan Optimasi Adaptive Moment Estimation," *J. Comput. Syst. Informatics*, vol. 4, no. 4, pp. 806–815, 2023, doi: 10.47065/josyc.v4i4.4014.
- [12] T. O. Hodson, "Root mean square error (RMSE) or mean absolute error (MAE): When to use them or not," *Geosci. Model Dev. Discuss.*, vol. 2022, pp. 1–10, 2022.